

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mislav Matezović

Zagreb, 2018. godina

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Bojan Jerbić, dipl. ing.

Student:

Mislav Matezović

Zagreb, 2018. godina

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru, prof. dr. sc. Bojanu Jerbiću, na stručnim savjetima i pruženoj pomoći pri izradi ovoga rada.

Također se zahvaljujem dr. sc. Bojanu Šekoranji na stručnim savjetima tokom izrade ovoga rada.

Mislav Matezović



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student:

Mislav Matezović

Mat. br.: 0035197063

Naslov rada na
hrvatskom jeziku:

**ROBOTSKO IZUZIMANJE NEORIJENTIRANIH PREDMETA
RADA IZ KUTIJE**

Naslov rada na
engleskom jeziku:

ROBOTIC BIN PICKING

Opis zadatka:

U sklopu zadatka potrebno je razviti upravljački program za robotsko rukovanje predmetima rada u nestrukturiranoj okolini. Nestrukturirana okolina ovdje podrazumijeva predmete rada slobodno raspoređene u transportnoj kutiji koje je potrebno prebacivati u nosač predmeta na radnom mjestu. Potrebno je proučiti i odabrati metodu lokalizacije primjenom robotskog 2D i 3D vizijskog sustava.

Eksperimentalno utvrditi potrebna vremena i mogućnosti izuzimanja predmeta 2D vizijom te usporediti s 3D vizijskim sustavom. Razvijenu primjenu provjeriti koristeći opremu dostupnu u Laboratoriju za projektiranje izradbenih i montažnih sustava.

Zadatak zadan:

30. studenog 2017.

Rok predaje rada:

1. rok: 23. veljače 2018.

2. rok (izvanredni): 28. lipnja 2018.

3. rok: 21. rujna 2018.

Predviđeni datumi obrane:

1. rok: 26.2. - 2.3. 2018.

2. rok (izvanredni): 2.7. 2018.

3. rok: 24.9. - 28.9. 2018.

Zadatak zadao:

prof. dr. sc. Bojan Jerbić

Predsjednik Povjerenstva:

Izv. prof. dr. sc. Branko Bauer

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA	IV
POPIS OZNAKA	V
SAŽETAK	VI
SUMMARY	VII
1. Uvod	1
1.1 Opis problema	1
1.2 Strojni vid	2
1.3 iRVision	2
1.3.1 2D vizijski sustav	2
1.3.2 3D vizijski sustav	3
1.4 Roboti	4
1.4.1 FANUC LR Mate 200iC/5L	4
1.4.2 FANUC M-10iA	5
2. Kalibracija kamere	7
2.1 Kalibracija korisničke ravnine	7
2.2 2D kalibracija	7
2.3 3D kalibracija	8
3. Učenje vizijskih procesa	10
3.1 2D vizijski proces	10
3.2 3D vizijski proces	18
4. Izvedba programa	23
4.1 Izvedba 2D programa	23
4.2 Dijagram toka 2D programa	25
4.3 Slikovni prikaz 2D programa	26
4.4 Izvedba 3DL programa	28
4.5 Dijagram 3DL programa	29
4.6 Slikovni prikaz 3DL programa	30
5. Zaključak	33
LITERATURA	34
PRILOZI	35
KOD PROGRAMA	36

POPIS SLIKA

Slika 1.	Predmeti izuzimanja	1
Slika 2.	Predmeti izuzimanja - druga strana	1
Slika 3.	Sony XC-56 kamera	3
Slika 4.	FANUC V-500iA senzor s kamerom	3
Slika 5.	FANUC LR Mate 200iC/5L	4
Slika 6.	FANUC LR Mate 200iC/5L dimenzije	4
Slika 7.	FANUC M-10iA	5
Slika 8.	FANUC M-10iA dimenzije	6
Slika 9.	Točke potrebne za kalibraciju korisničke ravnine	7
Slika 10.	Prikaz pronađenih točaka kalibracijske mreže kod 2D vizije	8
Slika 11.	Prikaz pronađenih točaka kalibracijske mreže kod 3D vizije	9
Slika 12.	Prikaz snimanja kalibracijske mreže	9
Slika 13.	Prikaz postavki 2D vizijskog procesa	11
Slika 14.	Prikaz početnog modela 2D vizijskog procesa	12
Slika 15.	Prikaz početnog modela 2D vizijskog procesa - druga strana	12
Slika 16.	Primjer potrebnog modela za predmet pod kutem	13
Slika 17.	Prikaz konačnog modela 2D vizijskog procesa	13
Slika 18.	Prikaz maskiranja nepotrebnih bridova	14
Slika 19.	Prikaz pronađenih predmeta	14
Slika 20.	Prikaz postavki GPM lokacijskog alata	15
Slika 21.	Prikaz ugnjiježdjenog GPM programskog alata	16
Slika 22.	Prikaz pronađenih predmeta u M3DM vizijskom procesu	17
Slika 23.	Prikaz pronađenih predmeta u M3DV vizijskom procesu	17
Slika 24.	Prikaz maskiranja prozora traženja predmeta	18
Slika 25.	Prikaz opcija 3DL ravninskog alata	19
Slika 26.	Prikaz pronađenih točaka na maloj površini	20
Slika 27.	Prikaz pronađenog predmeta 3DL vizijom	20
Slika 28.	Prikaz pronađenog predmeta pod kutem 2D vizijom u 3DL procesu	21
Slika 29.	Prikaz pronađenog predmeta pod kutem 3DL procesom	21
Slika 30.	Prikaz šuma kod pronađenog predmeta 3DL procesom	21
Slika 31.	Prikaz drugog pronađenog predmeta pod kutem 3DL procesom	22
Slika 32.	Prikaz šuma kod drugog pronađenog predmeta 3DL procesom	22
Slika 33.	Prikaz adaptivne hvataljke	23
Slika 34.	Prikaz troprsnice hvataljke	24
Slika 35.	Prikaz šuma vizijskog procesa za ravninski problem	24
Slika 36.	Slika dijagrama toka 2D programa	25
Slika 37.	Trženje predmeta u nesređenoj okolini	26
Slika 38.	Prilaz predmetu	26
Slika 39.	Izmjena alata	27
Slika 40.	Traženje predmeta u XY ravnini	27
Slika 41.	Izuzimanje predmeta	28

Slika 42. Industrijska rasvjeta	28
Slika 43. Slika dijagrama toka 3DL programa	29
Slika 44. Prva pozicija traženja predmeta	30
Slika 45. Druga pozicija traženja predmeta	30
Slika 46. Prilaz predmetu 3DL procesa	31
Slika 47. Drugi kadar prilaza predmetu	31
Slika 48. Izuzimanje predmeta	32
Slika 49. Odlaganje predmeta	32

POPIS TABLICA

Tablica 1.	Dimenzije predmeta izuzimanja	2
Tablica 2.	Karakteristike kamere Sony XC-56	3
Tablica 3.	Karakteristike LR Mate 200iC/5L	5
Tablica 4.	Karakteristike M-10iA	5

POPIS OZNAKA

d_m	Promjer provrta
d_v	Promjer veće kružnice

SAŽETAK

U ovom radu uspoređuje se primjena 2D i 3DL tehnologija robotskog vida za izuzimanje predmeta iz nesređene okoline (kutija). Na početku su objašnjeni vizijski sustavi i njihove karakteristike. Opisani su postupci kalibracije oba tipa vizijskih sustava. U drugom dijelu rada opisana je izrada algoritama za prepoznavanje predmeta pomoću korištenih vizijskih sustava. Razvijeni algoritmi ispitani su u laboratorijskim uvjetima i dobiveni rezultati obrađeni su u završnom dijelu rada.

Ključne riječi: robotski vid, iRVision, Fanuc, nesređena okolina

SUMMARY

This paper deals with comparison of two vision processes, a 2D one and a 3DL, for solving a bin picking problem. Software used in this paper is FANUC's iRVision. Brief description of machine vision is given at the beginning. After that it is shown how to calibrate both vision processes, followed by how to teach both processes to find items. In the end results are compared.

Key words: robotic vision, iRVision, Fanuc, bin picking

1. Uvod

1.1. Opis problema

Tema ovoga rada je uspoređivanje dvije metode za izuzimanje predmeta iz nesređene okoline. Prva metoda je pomoću 2D vizijskog procesa pomoću dviju hvataljki. Druga metoda je izravno izuzimanje predmeta 3D vizijskim sustavom. Predmeti koji se izuzimaju su dvije vrste konusnih zupčanika, prikazani na slikama 1 i 2. Roboti koji se koriste su FANUC LR Mate 200iC/5L (2D proces) i FANUC M-10iA (3D proces).



Slika 1. Predmeti izuzimanja



Slika 2. Predmeti izuzimanja - druga strana

Tablica 1. Dimenzije predmeta izuzimanja

Dimenzija	Tip 1	Tip 2
Masa	1 kg	0.7 kg
Visina	43.4 mm	37.5 mm
Unutarnji promjer	30.5 mm	30.5 mm
Vanjski promjer	95.8 mm	86.8 mm

1.2. Strojni vid

Strojni vid je tehnologija koja se koristi za analizu slike i dobivanje informacija iz slike, te postojećim tehnologijama omogućuje nove primjene i veću automatizaciju procesa. Koristi se kod automatizirane inspekcije, kontrole procesa i vođenja robota. Informacije koje se dobivaju iz slike mogu biti u rasponu od jednostavnog signala, koji samo javlja o ispravnosti predmeta, do složenijeg skupa podataka o identitetu, poziciji ili orijentaciji predmeta.

Strojni vid je danas neophodan dodatak svakom procesu jer omogućuje fleksibilnije manipuliranje s predmetima. Umjesto da predmeti budu u točno određenoj poziciji, robot uz pomoć kamere može locirati predmet u radnoj okolini i izuzeti ga uzimajući u obzir podatke o poziciji i orijentaciji.

Vizijski sustav se sastoji od kamere kao senzora i algoritma za obradu slike. Najčešće se koristi kamera za 2D viziju, ali mogu se koristiti i kamere za 3D viziju, rendgenske kamere, infracrvene kamere te kamere za spektralno snimanje.

Nakon što se slika snimi ona se mora obraditi u nekom programskom alatu kako bi se dobile tražene informacije. Programski alat koji se koristi u ovom radu je FANUC-ov iRVision.

1.3. iRVision

iRVision je FANUC-ov programski alat za robotsko upravljanje uz pomoć vizije. Omogućuje robotima da lociraju predmet pomoću 2D ili 3D vizije. Potpuno je integriran s robotom, te nakon učenja procesa ne zahtjeva vanjski uređaj. Također treba napomenuti da se i učenje procesa može odvijati preko upravljačke jedinice robota, ali je praktičnije preko računala. U ovom radu uspoređuje se 2D i 3D vizijski sustavi za izuzimanje istih predmeta.

1.3.1. 2D vizijski sustav

iRVision-ov 2D vizijski sustav omogućuje prepoznavanje pozicije predmeta u XY ravnini te kut zakreta oko Z osi. Usprkos nemogućnosti prepoznavanja visine Z i kuteva zakreta oko X i Y ravnina ovaj tip vizije korišten je za izuzimanje predmeta iz kutije. Nepoznati parametri kompenzirani su hvaljkom što će biti opisano kasnije.

Kamera koja se koristi je Sony XC-56 prikazana na slici 3.

Tablica 2. Karakteristike kamere Sony XC-56

Rezolucija	VGA (648x494 piksela)
Brzina snimanja	30 slika po sekundi
Izlazni konektor	12 pinova
Dimenzije	29x29x30 mm
Masa	50 g
Napon	DC 12 V
Snaga	1.5 W

**Slika 3. Sony XC-56 kamera**

1.3.2. 3D vizijski sustav

Kombinacijom 2D vizijskog sustava i dvije laserske zrake dobije se iRVisionov 3DL vizijski proces. Nepoznati parametri 2D vizijskog sustava dobiju se odbijanjem dvaju snopova lasera. Iako je ova metoda kompliciranija za učenje procesa omogućuje direktno izuzimanje predmeta bez potrebe za izmjenom alata.

Za 3D viziju koristi se FANUC-ov senzor V-500iA.

**Slika 4. FANUC V-500iA senzor s kamerom**


1.4. Roboti

1.4.1. FANUC LR Mate 200iC/5L

FANUC LR Mate 200iC/5L je robot sa šest stupnjeva slobode. Ima nosivost od 5 kg, te se koristi uzimanje i prijenos predmeta, micanje materijala, sklapanje proizvoda i u edukativne svrhe.



Slika 5. FANUC LR Mate 200iC/5L



Slika 6. FANUC LR Mate 200iC/5L dimenzije

Tablica 3. Karakteristike LR Mate 200iC/5L

Stupnjevi slobode	6
Nosivost	5 kg
Doseg	892 mm
Ponovljivost	± 0.02 mm

1.4.2. FANUC M-10iA


FANUC M-10iA je također robot sa šest stupnjeva slobode. Ima nosivost od 10 kg, te odlične karakteristike brzine za svoju klasu. Ima mogućnost rada u uskim radnim prostorima zbog malih dimenzija zglobova.



Slika 7. FANUC M-10iA

Tablica 4. Karakteristike M-10iA

Stupnjevi slobode	6
Nosivost	10 kg
Doseg	1422 mm
Ponovljivost	± 0.03 mm




Slika 8. FANUC M-10iA dimenzije

2. Kalibracija kamere

2.1. Kalibracija korisničke ravnine

Prije nego se krene kalibrirati vizijski proces potrebno je odrediti i kalibrirati korisničku ravninu. Oda-brana je metoda s četiri točke gdje je potrebno robota dovesti u određene točke u prostoru (ishodište koordinatnog sustava, točku u smjeru X osi, točku u smjeru Y osi i ishodište za određivanje osi) prikazano na slici 9.

Isti proces se obavlja za svaku drugu ravninu koja se koristi u procesu.



Slika 9. Točke potrebne za kalibraciju korisničke ravnine

2.2. 2D kalibracija


Nakon što se kalibrirala korisnička ravnina slijedi kalibracija u programskom alatu iRVision. U sučelju se odabere Alat za kalibraciju kamere (eng. *Camera Calibration Tools*), zatim Novi alat i zadnje se odabere Alat za kalibraciju pomoću kalibracijske mreže (eng. *Grid Pattern Calibration Tool*).

Na desnoj strani sučelja su postavke kalibracije. Potrebno je odabrati koja se kamera koristi (Sony XC-56 u ovom radu), zatim vrijeme ekspozicije, broj korisničkog sučelja, razmak krugova na kalibracijskoj mreži (20 mm), broj ravnina snimanja (2), drži li robot kalibracijsku mrežu, broj kalibracijske

mreže u kojoj se nalazi kalibracijska mreža, odabir perspektivne ili ortogonalne projekcije, te želi li se pomaknuti žarišna točka kamere.

Nakon odabira potrebnih postavki potrebno je snimiti kalibracijsku mrežu iz dvije točke. Razlog je činjenice da se koristi kamera montirana na robotu. Preporučuje se udaljenost od oko 150 mm između točki snimanja kako bi se veličina kružnica dovoljno promijenila.

Nakon snimanja na prozoru programskog alata pronađene točke su prikazane zelenim križevima. Potrebno je provjeriti točnost snimanja te ukloniti nepotrebne ili krivo pronađene točke.




Slika 10. Prikaz pronađenih točaka kalibracijske mreže kod 2D vizije

2.3. 3D kalibracija


Za kalibraciju 3D vizije odabire se Alat za kalibraciju 3D vizije s laserima (eng. *3D Laser Vision Calibration*).

3D kalibracija je slična 2D kalibraciji, jedina razlika je potreba da se robot pozicionira tako da se sjecište laserskih snopova postavi u ishodište koordinatnog sustava. Postavke kalibracije su iste kao i kod 2D vizije, jedino su dodani parametri lasera: minimalni kontrast lasera, minimalni broj točaka lasera te maksimalni iznos greške lasera.

Kao i kod 2D kalibracije, 3D vizija se snima iz dvije ravnine. Preporuča se da je prva ravnina na otprilike 350 mm udaljenosti od kalibracijske mreže, a druga na 450 mm udaljenosti.



Slika 11. Prikaz pronađenih točaka kalibracijske mreže kod 3D vizije



Slika 12. Prikaz snimanja kalibracijske mreže

3. Učenje vizijskih procesa

Nakon što se kalibriraju kamere potrebno je naučiti vizijski proces kako bi se mogao prepoznati predmet u radnom prostoru.

3.1. 2D vizijski proces

2D vizijskim procesom može se dobiti položaj i orijentacija predmeta u XY ravnini. Robot preko kamere dobije razliku referentne naučene pozicije i stvarne pozicije predmeta u radnom prostoru. Zbog toga je potrebno prvo napraviti program izuzimanja predmeta bez vizije te nakon toga predmet ostaviti u točki izuzimanja kako bi ta točka bila referentna za viziju. U suprotnom bi se unijela greška te izuzimanje ne bi bilo moguće.

Nakon što se predmet postavi u referentni položaj u sučelju se odabere 2D vizijski proces. Odabere se prethodno naučena kalibracija kamere. Namjesti se ekspozicija kamere na vrijednost gdje je dobar kontrast predmeta i podloge. U opcijama se odabere GPM lokacijski alat (eng. *GPM Locator Tool*). Nakon toga snimi se trenutno stanje radnog prostora, označi se dio gdje je predmet te programski alat prikaže koje bridove predmeta je prepoznao. Ukoliko se neki od bitnih bridova nije prepoznao potrebno je namjestiti ekspoziciju kamere ili poboljšati svjetlosne uvjete. Oni bridovi koji nisu potrebni za prepoznavanje predmeta a pronađeni su mogu se maskirati s opcijom Učenje maske (eng. *Training mask*), prikazano na slici 18.

Početni pristup predmetima izuzimanja je bio da se uz provrt traži i vanjska ruža zupčanika. To je dobar pristup kada je predmet ravan u XY ravnini, ali kada je pod kutem oko osi X i/ili Y programski alat više ne može prepoznati predmet. Na slikama 14 i 15 su prikazani početni modele vizijskog procesa. Slijedeći korak je bila provjera robusnosti modela na predmet koji je pod kutem. Rezultat provjere je da predmet nije moguće naći iz prethodno naučenog modela. Na slici 16 prikazan je potreban model za predmet pod kutem. Budući da je to samo jedna od beskonačno mnogo mogućnosti u kojoj se predmet može nalaziti odbačen je početni pristup.

Vision Tools

2-D Single-View Vision Process

- GPM Locator Tool 1
 - Measurement Output Tool 1
 - GPM Locator Tool 2
 - Conditional Execution Tool 1

2-D Single Vision Process

Status: Trained

Camera Calibration: Trained

MISLAV1

Camera Setup: Trained

MISLAV

Exposure Mode: Fixed

Exposure Time: 10.000 ms. -- - + ++

Auto Exposure Area: Not Trained Train

Auto Exposure Adjust: 0 Mask

Number of Exposures: 1, 10.000 - 10.000 ms.

Multi Exposure Area: (0,0) 480x512 Train

Multi Exposure Mode: Deviation Mask

Multiple Locator Find Mode: Find Best

Number to Find: 3

Offset Mode: Fixed Frame Offset

Robot Holding the Part: This Controller, Group 1

User Tool Number: Not Selected

Image Logging Mode: Don't Log

Sort by: Parent Command Tool Level

Scale Desc.

Delete Duplicate Results If: < 20.0 pix. and < 180.0 deg.

Ref. Data Index To Use: This Index, index 1

Convert meas. to mm: ☐

Reference Data

Index: 1

Model ID: 1

Part Z Height: 35.700 mm.

Reference Position Status: Set Set Ref. Pos.


Reference X: -0.947 mm.

Reference Y: 29.856 mm.


Reference R: 90.123 deg.

Limit Check Select: None selected


Slika 13. Prikaz postavki 2D vizijskog procesa



Slika 14. Prikaz početnog modela 2D vizijskog procesa




Slika 15. Prikaz početnog modela 2D vizijskog procesa - druga strana




Slika 16. Primjer potrebnog modela za predmet pod kutem

Daljnijim razmatranjem i poboljšavanjem svjetlosnih uvjeta dobio se konačni model 2D vizijskog procesa, prikazan na slici 17. Na slici 18 prikazano je maskiranje nepotrebnih bridova.




Slika 17. Prikaz konačnog modela 2D vizijskog procesa



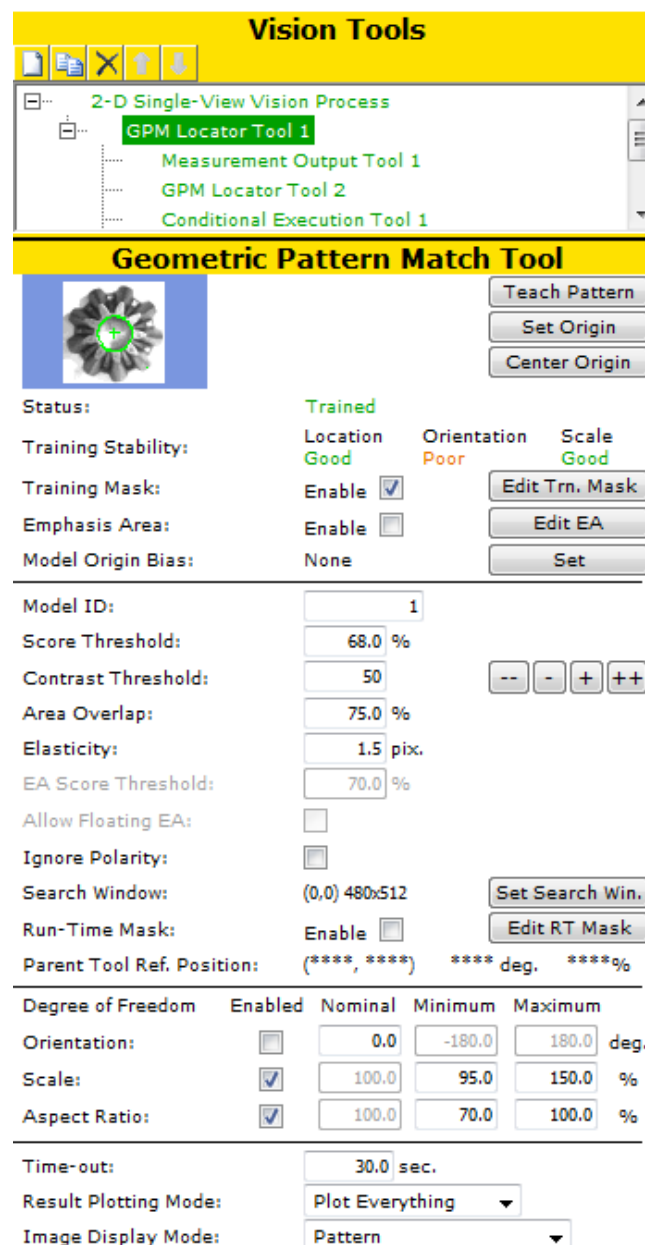
Slika 18. Prikaz maskiranja nepotrebnih bridova

Razlog uzimanja samo kružnice za prepoznavanje je jednostavnost geometrije te mogućnost pronalaženja kada je predmet pod kutem. Kamera kružnicu pod kutem vidi kao elipsu, što je moguće obuhvatiti s tri parametra koja ima GPM lokacijski alat. Ti parametri su orijentacija, skaliranje i odnos stranica (eng. *Aspect Ratio*). Orijentacija se ne može odrediti kod kružnice te se taj parametar ne traži zbog ubrzavanja procesa. Skaliranjem se obuhvaćaju predmeti koji se nalaze na različitim visinama. Odnosom stranica moguće je pronalaženje elipsa s modelom kružnice.

Uz ta tri parametra potrebno je i odrediti parametre za ocjenu pronalaženih rezultata. Pragom ocjene određuje se koja je minimalna ocjena potrebna za pronalaženje predmeta. Pragom kontrasta određuje se minimalni kontrast, a preklapanjem površine minimalni postotak površine potrebne za pronalaženje predmeta. Parametrom elastičnosti moguće je regulirati osjetljivost procesa.



Slika 19. Prikaz pronađenih predmeta




Slika 20. Prikaz postavki GPM lokacijskog alata

Iako je ovaj proces dosta robustan za pronalaženje predmeta u nesređenoj okolini s 2D vizijom, nije se pokazao kao zadovoljavajuće robusan. Razlog je način određivanje prioriteta predmeta. U ovom procesu prioritet se određivao ocjenom pronađenih predmeta. Što je ocjena bila veća to je predmet imao veći prioritet. Programski alata određuje ocjenu temeljem naučene slike, te su predmeti s manjim kutem imali veću ocjenu. To je dovodilo do situacija kad se predmet s najvećom ocjenom nalazio ispod drugog predmeta ali je kružnica potpuno vidljiva i predmet nije pod kutem. Takvi predmeti iako su imali najbolju ocjenu nisu se mogli izuzeti, što je dovodilo do beskonačnih petlji jer je proces htio izuzeti predmet koji nije mogao.

Taj problem je riješen mijenjanjem prioriteta procesa iz ocjene u skaliranje predmeta. Predmeti bliži kameri su veći od onih koji su dalji, te se traženjem najvećih kružnica osiguravalo izuzimanje uvijek predmeta koji su na vrhu kutije. I mali i veliki predmet imaju isti promjer provrta i time je zadovoljen uvjet kompatabilnosti vizijskog procesa. Usprkos tome novi problem koji se pojavio je taj da manji predmet na jednoj strani ima dvije kružnice (slika 17) te kamera vidi vanjsku bolje od unutarne. Ta vanjska kružnica je 16% veća od provrta predmeta, što je dovodilo do loših rezultata jer nije osigurano linearno skaliranje veličine kružnica. Izradom dvaju vizijskih procesa odvojilo se traženje kružnica, jedan vizijski proces (M2DV u programu) tražio je provrte na predmetu, a drugi vizijski proces (M2DM) tražio je veću vanjsku kružnicu na malom predmetu. Jednoliko skaliranje kružnica dobilo se jednakošću


$$d_m = 0.965 * d_v,$$

gdje su d_m promjer provrta (manje kružnice) i d_v promjer veće kružnice. Preklapanje parametara vizijskih procesa je nastao kada su predmeti bili naslagani na više od tri reda iz razloga da je skaliranje provrta iznosilo više od 116%. Kako je odnos početnih stanja bio 100% naspram 116% vizijski proces koji traži provrte trebao je nekako poništiti pronalaženje vanjske kružnice manjeg predmeta. Korišten je ugniježđeni GPM lokacijski alat unutra GPM lokacijskog alata u M2DV procesu (slika 21). Poboljšavanjem svjetlosnih uvjeta omogućilo se traženje i vanjske kružnice i provrta.




Slika 21. Prikaz pronađenih točaka kalibracijske mreže kod 3D vizije

Na slikama 22 i 23 prikazani su prepoznati predmeti vizijskih procesa. Može se vidjeti kako su uspješno pronađeni samo traženi predmeti bez preklapanja.



Slika 22. Prikaz pronađenih predmeta u M3DM vizijskom procesu




Slika 23. Prikaz pronađenih predmeta u M3DV vizijskom procesu

3.2. 3D vizijski proces

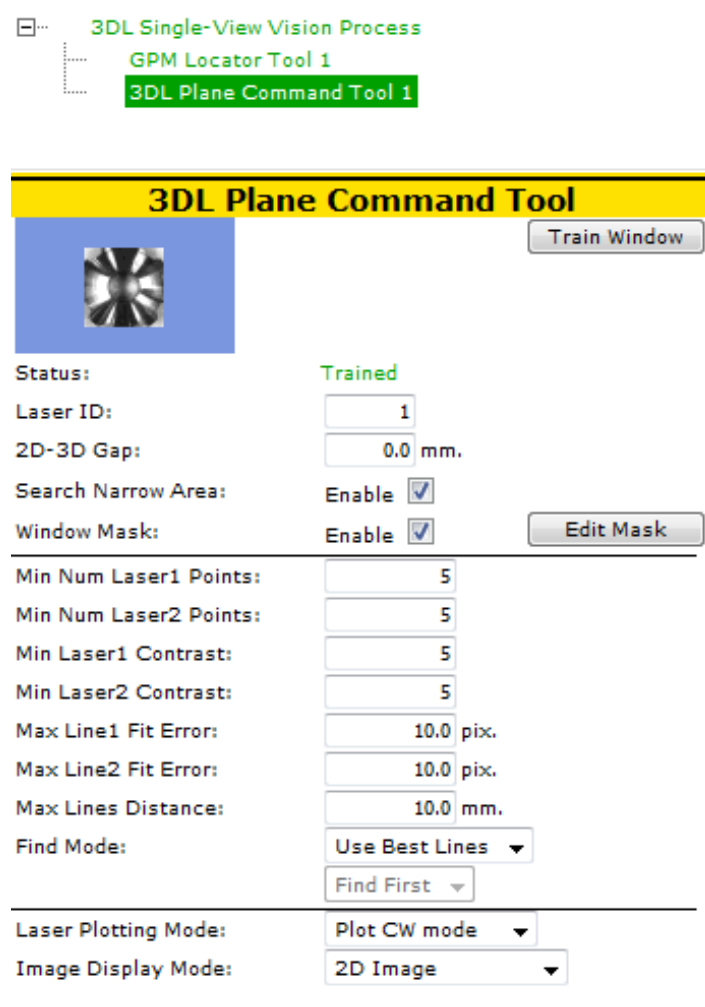
3D vizijski proces rješava problem nepoznatih parametara 2D vizijskog procesa, visinu Z te kuteve zakreta oko X i Y osi. Postupak učenja je sličan kao i kod 2D vizijskog procesa. Prvo je potrebno napraviti program izuzimanja bez vizije zatim naučiti vizijski proces.

U iRVision sučelju odabere se novi 3DL vizijski proces koji se sastoji od dva alata: GPM lokacijskog alata koji je identičan kao i kod 2D vizije te 3DL ravninskog alata (eng. *3DL Plane Command Tool*). Učenje GPM lokacijskog alata isto je kao i 2D vizije, te se koristi isti način traženja kružnice provrta.

3DL ravninski alat se kalibrira odabirom prozora u kojem se traže odbijene laserske točke. Ukoliko predmet ima puno utora i razlika visina u opciji 2D-3D razmak (eng. *2D-3D Gap*) se upiše najveća vrijednost razmaka. Opcija Traženje na uskoj površini (eng. *Search Narrow Area*) povećava točnost ali produljuje vrijeme traženja. Maska prozora (eng. *Window Mask*) omogućuje maskiranje neželjenih područja u prozoru traženja predmeta. Razlog maskiranja su loši rezultati koji mogu pokvariti ukupni rezultat te uzrokovati krivim parametrima. Za predmete izuzimanja u ovom radu maskirao se provrt te ruža zuba i prostor među zubima (slika 24). Parametri koji se mogu podešavati su minimalni broj pronađenih točaka laserskih snopova 1 i 2, minimalni kontrast laserskih snopova 1 i 2, maksimalni broj piksela za koje se mogu pomaknuti točke snopova i na kraju maksimalna udaljenost laserskih snopova.




Slika 24. Prikaz maskiranja prozora traženja predmeta




Slika 25. Prikaz opcija 3DL ravninskog alata

Problemi koji nastaju kod ovog predmeta su mala površina na jednoj strani te sjajna i konusna površina na drugoj strani predmeta. Na slici 26 se vidi kako laserske točke padaju na malu površinu i ako se predmet zarotira oko Z osi često programski alat ne može pronaći predmet zbog premalog broja točaka. Slika 26 je prikaz jednog od boljih pokušaja te se može vidjeti kako se laserski snop 2 jedva odbio na rubu provrta.




Slika 26. Prikaz pronađenih točaka na maloj površini

Druga strana, iako veća od prve, je sjajna i konusna što uzrokuje loše odbijanje laserskih snopova kada je predmet pod kutem. Kada je predmet ravan u XY ravnini moguće je pronaći predmet. Nije ga moguće naći iz prvog pokušaja ali kada ga se nađe dobiju se dobri kutevi. U programu se predmet traži u pet pokušaja nakon čega izbací korisnički alarm. Pronađeni predmet u XY ravnini prikazan je slici 27.




Slika 27. Prikaz pronađenog predmeta 3DL vizijom


Kada se predmet nalazi pod kutem 2D dio vizije ga pronađe (slika 28), ali laserski dio nije dovoljno robustan. Na slici 29 laserski snopovi su se odbili od oba dvije strane predmeta te su normale laserskih točaka poništile. Zbog toga su se dobili dobri kutevi oko X i Y ravnine. Kad se odmah nakon pokrenulo pronalaženje istog predmeta pod istim svjetlosnim uvjetima pojavio se šum te su dobiveni krivi kutevi. Treći pokušaj nije pronašao predmet, te su daljnja traženja davala slične rezultate. Razlog zašto se u procesu ne može implementirati višestruko pronalaženje predmeta je taj da programski alat ne može odrediti točnost dobivenog rezultata. Programski alat ili nađe ili ne nađe predmet te, ako bi se pokušalo unijeti granicu za točnost kuta ne bi se moglo izuzeti predmete iz potpuno nesređene okoline.



Slika 28. Prikaz pronađenog predmeta pod kutem 2D vizijom u 3DL procesu




Slika 29. Prikaz pronađenog predmeta pod kutem 3DL procesom




Slika 30. Prikaz šuma kod pronađenog predmeta 3DL procesom

Na slikama 31 i 32 prikazan je isti problem za drugu orijentaciju predmeta.



Slika 31. Prikaz drugog pronadenog predmeta pod kutem 3DL procesom




Slika 32. Prikaz šuma kod drugog pronadenog predmeta 3DL procesom

4. Izvedba programa

4.1. Izvedba 2D programa


2D program izvodi se u nekoliko dijelova. Prvo se traži 2D vizijskim procesom najviši predmet u kutiji, taj dio je opisan u poglavlju 3.1. Nakon što se pronade predmet robot pomoću adaptivne hvataljke izuzme predmet iz kutije. Adaptivna hvataljka je prikazan na slici 33. Sastoji se od četiri elektromagneta koji vise na užadi. Elektromagneti se pale i gase se preko robotskog signala.



Slika 33. Prikaz adaptivne hvataljka

Nakon faze izuzimanja pomoću senzora sile provjeri se uspješnost izuzimanja. Ukoliko predmet nije uhvaćen robot se vraća u poziciju snimanja te pokušava opet. Ako je predmet uspješno uhvaćen robot ga ostavlja na ravnu podlogu.

Slijedi izmjena alata te završna faza gdje se rješava obični ravninski problem. Alat za izuzimanje kod ravninskog problema je tropsna hvataljka, slika 34. Robot se dovede u poziciju snimanja. Pomoću dva vizijska procesa, jedan za manji predmet i jedan za već, uzima se predmet i stavlja na potrebno mjesto. Nakon toga ponovno se izmjeni alat te je jedan ciklus završen i slijedi drugi.




Slika 34. Prikaz troprsne hvataljke




Slika 35. Prikaz vizijskog procesa za ravninski problem

4.2. Dijagram toka 2D programa




Slika 36. Slika dijagrama toka 2D programa


4.3. Slikovni prikaz 2D programa




Slika 37. Traženje predmeta u nesređenoj okolini




Slika 38. Prilaz predmetu




Slika 39. Izmjena alata



Slika 40. Traženje predmeta u XY ravnini



Slika 41. Izuzimanje predmeta

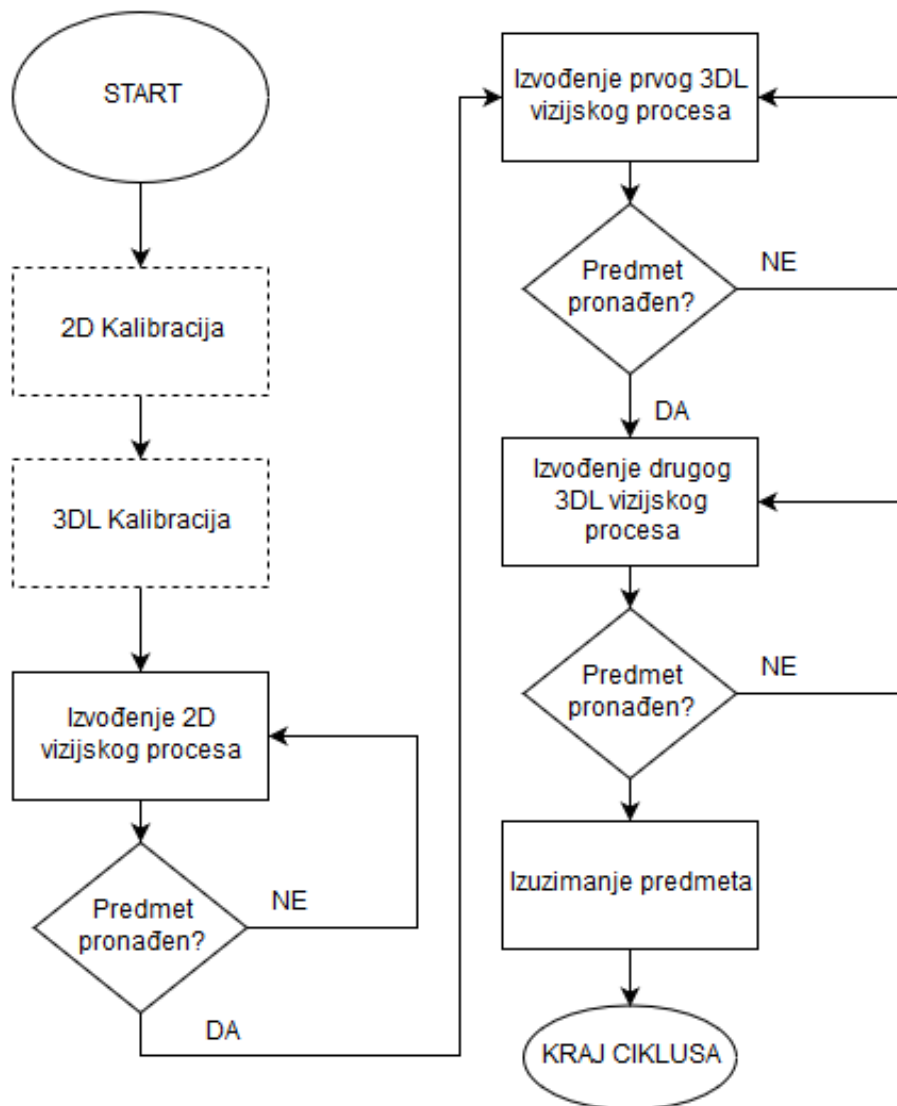


Slika 42. Industrijska rasvjeta

4.4. Izvedba 3DL programa


Prvi korak je pronalaženje predmeta 2D vizijskim procesom kako bi se robot mogao pomaknuti u poziciju u kojoj laserski snopovi padaju na predmet. Nakon toga traži se predmet pomoću 3DL vizijskog procesa. Nakon što se predmet pronađe robot se pomakne u drugu točku snimanja te se ponovno traži 3DL vizijskim procesom. Zadnji korak je prilaz i uzimanje predmeta.

4.5. Dijagram 3DL programa




Slika 43. Slika dijagrama toka 3DL programa


4.6. Slikovni prikaz 3DL programa




Slika 44. Prva pozicija traženja predmeta




Slika 45. Druga pozicija traženja predmeta




Slika 46. Prilaz predmetu 3DL procesa



Slika 47. Drugi kadar prilaza predmetu



Slika 48. Izuzimanje predmeta



Slika 49. Odlaganje predmeta

5. Zaključak

U ovom radu bilo je potrebno usporediti 2D i 3DL vizijske sustave programskog alata iRVision za izuzimanje predmeta iz nesredene okoline.

2D vizijski sustav pokazao se robusnijim od 3DL vizijskog sustava za predmet koji se izuzimao u ovom radu. Jednostavna geometrija kružnice provrta lako se mogla naći i pod kutem korištenjem dobrih parametara procesa. Iako 2D vizijski sustav omogućuje samo pronalaženje u XY ravnini, adaptivnom hvataljkom riješio se problem nepoznate koordinate Z te kuteva zakreta oko X i Y osi. Mana ove metode je dugo trajanje procesa. Dva vizijska procesa, dvije vrste alata, te korištenje užadi usporili su ovaj proces.

3DL proces trebao je otkloniti mane 2D procesa zbog mogućnosti potpunog definiranja položaja u prostoru. Kombinacijom 2D vizijskog sustava i dva laserska snopa omogućuje se direktno izuzimanje predmeta i potpuna manipulacija istog. Unatoč velikim mogućnostima 3DL vizijskog procesa, predmet koji se izuzimao u ovom radu pokazao se nepovoljnim. Mala površina na jednoj strani, te sjajna i konusan površina na drugoj strani predmeta pokazale su se neprikladnim za laserske snopove. Uspješno je riješeno izuzimanje predmeta koji nemaju kut zakreta oko X i Y osi neovisno o Z koordinati. Predmeti koji su zaokrenuti oko X i Y osi ne mogu se izuzeti korištenjem 3DL vizijskog procesa. Ovaj proces kada funkcionira puno je brži od 2D vizijskog procesa i omogućuje manipuliranje predmetom odmah nakon izuzimanja, bez potrebe za izmjenom alata.

Literatura

- [1] *Fanuc Robot series R-30 iA/ R-30 iA Mate controller iR Vision operator's manual*, 2009.
- [2] *Fanuc Robot series Force Sensor operator's manual*, 2008.
- [3] Jerbić B., Nikolić G., Vranješ B., Kunica Z. *Projektiranje automatskih montažnih sustava*, Kigen, Zagreb, 2009.

PRILOZI

1 CD-R

2 Kod programa

Kod programa

2D program:

MISLAV

```
1: LBL[1000] ;
2: R[13]=0 ;
3: R[14]=0 ;
4: CALL MAGNETNA ;
5: CALL M_IZM_ALATA ;
6: CALL M_3_PRST ;
7: IF R[13]=1,JMP LBL[90] ;
8: CALL M3PV ;
9: LBL[90] ;
10: CALL M_IZM_AL2 ;
11: JMP LBL[1000] ;
/POS
/END
```

MAGNETNA

```
1: UFRAME_NUM=4 ;
2: UTOOL_NUM=5 ;
3: R[14]=0 ;
4: LBL[1] ;
5: R[14]=R[14]+1 ;
6: IF R[14]>4,JMP LBL[2] ;
7: J P[1] 100% FINE ;
8: R[15]=0 ;
9: R[16]=0 ;
10: CALL M2DV ;
11: CALL M2DM ;
12: IF (R[15]>116),JMP LBL[504] ;
13: IF R[16]>116,JMP LBL[504] ;
14: IF (R[15]>R[16]*.965),JMP LBL[500] ;
18: LBL[500] ;
19: DO[104]=ON ;
20: L P[2] 500mm/sec FINE VOFFSET,VR[1] ;
21: L P[11] 125mm/sec FINE VOFFSET,VR[1] ;
22: L P[13] 125mm/sec FINE VOFFSET,VR[1] ;
23: JMP LBL[503] ;
24: LBL[501] ;
25: DO[104]=ON ;
```

```

26:L P[2] 400mm/sec FINE VOFFSET,VR[2] ;
27:L P[11] 125mm/sec FINE VOFFSET,VR[2] ;
28:L P[13] 125mm/sec FINE VOFFSET,VR[2] ;
29: LBL[503] ;
30:J P[4] 15% FINE ;
31: IF ($CCC_GRP[1].$FS_FORCE[3]*100<(-1.2)),JMP LBL[1] ;
32: JMP LBL[507] ;
33: LBL[504] ;
34: DO[104]=ON ;
35: IF (R[15]<.965*R[16]),JMP LBL[505] ;
36:L P[8] 1000mm/sec FINE VOFFSET,VR[1] ;
37:L P[9] 125mm/sec FINE VOFFSET,VR[1] ;
38:L P[14] 150mm/sec FINE VOFFSET,VR[1] ;
39: JMP LBL[506] ;
40: LBL[505] ;
41:L P[8] 1000mm/sec FINE VOFFSET,VR[2] ;
42:L P[9] 125mm/sec FINE VOFFSET,VR[2] ;
43:L P[14] 150mm/sec FINE VOFFSET,VR[2] ;
44: LBL[506] ;
45:L P[12] 450mm/sec FINE ;
46: IF ($CCC_GRP[1].$FS_FORCE[3]*100<(-1.2)),JMP LBL[1] ;
47: LBL[507] ;
48:J P[5] 25% FINE ;
49:L P[6] 125mm/sec FINE ;
50: DO[104]=OFF ;
51:L P[3] 125mm/sec FINE ;
52:L P[10] 4000mm/sec FINE ;
53:L P[7] 4000mm/sec FINE ;
54: JMP LBL[91] ;
55: LBL[99] ;
56: UALM[1] ;
57: LBL[2] ;
58: UALM[2] ;
59: LBL[91] ;
/END

```

M2DM

```

1: VISION RUN_FIND 'M2DM' ;
2: VISION GET_OFFSET 'M2DM' VR[2] JMP LBL[888] ;
3: R[16]=VR[2].MES[1] ;
4: LBL[888] ;
/END

```

M2DV

```
1: VISION RUN_FIND 'M2DV' ;
2: VISION GET_OFFSET 'M2DV' VR[1] JMP LBL[999] ;
3: R[15]=VR[1].MES[1] ;
4: LBL[999] ;
/END
```

M_3PRST

```
1: UFRAME_NUM=3 ;
2: UTOOL_NUM=4 ;
3: J P[1] 100% FINE ;
4: VISION RUN_FIND 'M3PM' ;
5: VISION GET_OFFSET 'M3PM' VR[1] JMP LBL[95] ;
6: L P[2] 4000mm/sec FINE VOFFSET,VR[1] ;
7: L P[3] 250mm/sec FINE VOFFSET,VR[1] ;
8: CALL GR_OP ;
9: L P[2] 250mm/sec FINE VOFFSET,VR[1] ;
10: L P[4] 4000mm/sec FINE ;
11: L P[5] 250mm/sec FINE ;
12: CALL GR_CL ;
13: L P[6] 250mm/sec FINE ;
14: R[13]=1 ;
15: LBL[95] ;
/END
```

M3PV

```
1: UFRAME_NUM=3 ;
2: UTOOL_NUM=4 ;
3: J P[1] 100% FINE ;
4: VISION RUN_FIND 'M3PV' ;
5: VISION GET_OFFSET 'M3PV' VR[1] JMP LBL[96] ;
6: L P[2] 3500mm/sec FINE VOFFSET,VR[1] ;
7: L P[3] 250mm/sec FINE VOFFSET,VR[1] ;
8: CALL GR_OP ;
9: L P[2] 250mm/sec FINE VOFFSET,VR[1] ;
10: L P[4] 4000mm/sec FINE ;
11: L P[5] 250mm/sec FINE ;
12: CALL GR_CL ;
13: L P[6] 250mm/sec FINE ;
14: LBL[96] ;
/END
```

M_IZM_ALATA

```
1: UFRAME_NUM=4 ;
2: UTOOL_NUM=5 ;
3:L P[1] 3000mm/sec FINE ;
4:L P[2] 100mm/sec FINE ;
5: CALL ALAT_OTP ;
6: WAIT .50(sec) ;
7:L P[3] 100mm/sec FINE ;
8:L P[7] 3000mm/sec FINE ;
9:L P[4] 3000mm/sec FINE ;
10:L P[5] 100mm/sec FINE ;
11: CALL ALAT_PRI ;
12: WAIT .50(sec) ;
13:L P[6] 100mm/sec FINE ;
/END
```

M_IZM_AL2

```
1: UFRAME_NUM=4 ;
2: UTOOL_NUM=4 ;
3:L P[1] 3000mm/sec FINE ;
4:L P[2] 100mm/sec FINE ;
5: CALL ALAT_OTP ;
6: WAIT .50(sec) ;
7:L P[3] 250mm/sec FINE ;
8:L P[7] 3000mm/sec FINE ;
9:L P[4] 3000mm/sec FINE ;
10:L P[5] 100mm/sec FINE ;
11: CALL ALAT_PRI ;
12: WAIT .50(sec) ;
13:L P[6] 150mm/sec FINE ;
14:L P[8] 4000mm/sec FINE ;
/END
```

3D program:

M2D

```
1: LBL[199] ;
2: R[11]=0 ;
3: R[12]=0 ;
4: UFRAME_NUM=3 ;
5: UTOOL_NUM=3 ;
6: CALL GR_CL ;
```



```
7:J P[1] 100% FINE ;
8: VISION RUN_FIND 'M_2D_NOVI' ;
9: VISION GET_OFFSET 'M_2D_NOVI' VR[1] JMP LBL[99] ;
10: CALL M25D ;
11: ;
12: LBL[99] ;
13: UALM[1] ;
/END
```

M25D

```
1: UFRAME_NUM=3 ;
2: UTOOL_NUM=3 ;
3: JMP LBL[79] ;
4: LBL[78] ;
5: R[11]=R[11]+1 ;
6: IF R[11]>3,JMP LBL[91] ;
7: LBL[79] ;
8:L P[1] 1700mm/sec FINE VOFFSET,VR[1] ;
9: VISION RUN_FIND 'M_3D_NOVI' ;
10: VISION GET_OFFSET 'M_3D_NOVI' VR[2] JMP LBL[78] ;
11: LBL[88] ;
12: R[12]=R[12]+1 ;
13: IF R[12]>4,JMP LBL[91] ;
14:L P[2] 500mm/sec FINE VOFFSET,VR[2] ;
15: VISION RUN_FIND 'M_3D_2_KOR' ;
16: VISION GET_OFFSET 'M_3D_2_KOR' VR[3] JMP LBL[88] ;
17:L P[3] 500mm/sec FINE VOFFSET,VR[3] ;
18:L P[4] 125mm/sec FINE VOFFSET,VR[3] ;
19: CALL GR_OP ;
20:L P[5] 125mm/sec FINE VOFFSET,VR[3] ;
21: ; 22:J P[6] 100% FINE ;
23:L P[7] 100mm/sec FINE ;
24: CALL GR_CL ;
25:L P[6] 100mm/sec FINE ;
26: R[12]=1 ;
27: LBL[91] ;
/END
```